

EV 주행 중 실시간 SOH 추정을 위한 Bi-directional LSTM 기반 임베디드 모델 설계

한동호*, 이상력*, 고은진*, 김종훈*
 충남대학교 에너지저장변환연구실*

Bi-directional LSTM based Embedded Model Design for Real-time SOH Estimation during EV driving condition

Dongho Han*, Sangryuk Lee*, Eunjin Ko*, Jonghoon Kim*
 Energy Storage Conversion Lab., Chungnam National University*

ABSTRACT

본 논문은 EV 주행환경 내, 실시간 SOH 추정을 위해 Ohmic resistance 기반의 라벨링 방법을 제안한다. 제안된 라벨링 방법을 적용함으로써 학습 데이터셋을 구축하며 시계열 예측 알고리즘으로 선정된 Bi-directional LSTM의 임베디드를 위해 Yocto project를 구축하였으며, 실제 주행 환경을 모사한 프로파일을 기반으로 알고리즘의 성능이 검증된다.

1. 서론

E-mobility 중에서 특히 EV와 같은 복잡한 어플리케이션의 내부에 알고리즘을 임베디드 형태로 운용하는 것은 항상 중요한 이슈입니다. Yocto project는 developer 뿐만 아니라 다양한 사용자들이 동일한 환경에서 소프트웨어의 관리 및 개발을 단순화할 수 있다는 큰 장점을 가진다. 특히 Yocto project 기반의 embedded system은 복잡한 system 내부에서 edge processing 역할을 수행할 수 있다. Sequential model의 Backpropagation through time(BPTT)는 하나의 time step에서 이전 시점의 gradient들까지 chain rule로 곱하는 연산에 기인한다. 또한 추후 데이터 sequence가 길어짐에 따라 estimation 성능이 감소하는 것을 대비하여 bi-directional LSTM model이 고려된다. Sequence data의 끝 부분의 정보를 사용할 수 없기 때문에 일반적으로 LSTM이나 GRU는 개체 명 인식과 같은 문제에서 성능이 감소하는 경우가 있다. 하지만, Bi-directional LSTM의 경우, sequential data에서 더 많은 정보를 추출할 수 있으며, 이는 더 좋은 모델의 성능을 의미한다. 양방향으로 데이터 시퀀스의 이전 부분과 이후 부분을 결합하여 예측하기 때문에 더욱 정확한 결과의 도출이 가능하다

2. Ohmic Resistance 라벨링에 따른 입력 구성

2.1 Labeling Criteria 적용 매커니즘

그림 1은 Ohmic resistance와 labeling results를 기반으로 battery degradation에 따라 구성되는 point 별 time-series input database를 나타낸다. Table 1에서 설정된 labeling 분류 기준 method가 적용되며, 다수의 라벨을 대표하여 예시로 일부 label이 제시된다. 노란색으로 표기된 부분이 최종적인 label이며 각 label 은 해당 point에서 도출된 ohmic 저항과

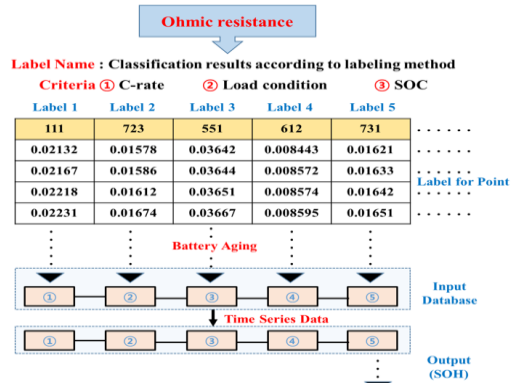


그림 1 추출된 Ohmic resistance 기반 Labeling 기준 적용 매커니즘
 Fig. 1 Labeling mechanism by point for configuring the input database of AI based time-series estimation model

대응된다. Point 별 Ohmic resistance는 battery의 degradation에 따라 적층되며 하나의 input database를 구성한다. 구성된 input database는 time series 형태로 나열되며 한번의 프로파일이 동작할 때 output에 해당하는 SOH가 산출된다.

2.2 Bi-directional LSTM 모델 설계 및 적용

Figure 2는 본 논문에서 최종적으로 제시된 Bi-directional LSTM model의 구조 및 backward and forward pass 매커니즘을 나타낸다. Bi-directional LSTM은 두개의 독립적인 LSTM cell을 기반으로 입력 데이터를 처리한다. 하나의 LSTM은 정방향으로 입력을 받으며, 다른 하나의 LSTM은 역방향으로 입력을 받는다. 이러한 구조는 neural network가 각 time step에서 양방향 정보를 모두 입력받을 수 있게 하며, Bi-directional LSTM의 출력은 정방향 LSTM과 역방향 LSTM의 출력을 결합하여 결정된다.




그림 2 Bi-directional LSTM의 구조 및 학습 프로세스
 Fig. 2 Architecture of Bi-directional LSTM and training process

3. 실시간 SOH 추정을 위한 검증 프로파일 적용

3.1 Yocto project의 세부 구성 및 Target board 적용

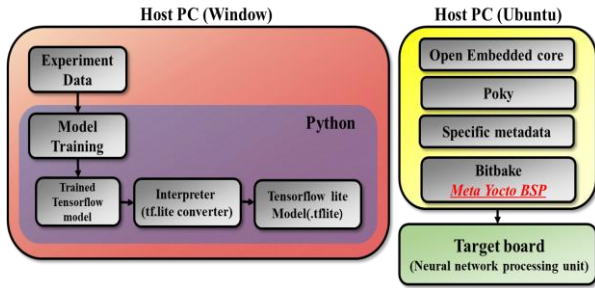


그림 3 Yocto project의 세부 구성 및 개발 Flow

Fig. 3 Detailed configuration and development of Yocto project

그림 3은 본 논문에서 제시하는 Yocto project의 세부 구성 및 실제 NPU 기반 target board에 AI 알고리즘을 탑재하기 위한 세부 개발 flow를 나타낸다. 그림에서 볼 수 있듯이 AI based Yocto project 구축을 위해 구글에서 제공하는 모델 최적화 라이브러리인 Tensorflow Lite가 사용된다. Tensorflow Lite는 개발자가 mobile, Internet of Things(IoT)기 등에서 AI model을 활용할 수 있도록 지원한다. Embedded system 내 AI 알고리즘을 구동하는것에 최적화되어 있으며, 지연 시간, 개인 정보 보호, 연결성, model 및 바이너리 축소, 전력 소비 감소 등 5가지 핵심 제약사항을 해결하였다.

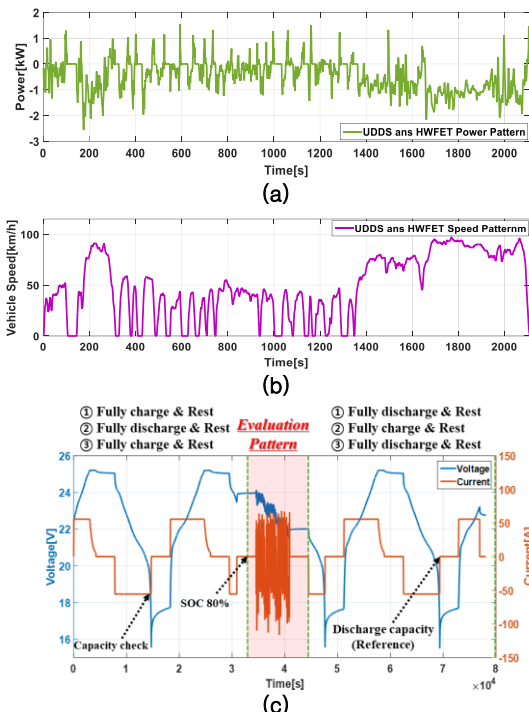


그림 4 임베디드 리눅스 타겟 보드 검증을 위한 테스트 프로파일 및 셋업, UDSS 와 HWFET의 (a) 파워패턴 및 (b) 속도패턴 (c) 최종 평가 패턴
Fig. 4 Test profile and setup for embedded linux target board validation, (a) power pattern and (b) speed pattern of UDSS and HWFET, (c) final evaluation pattern

Figure 11은 Yocto project based Embedded Linux target board를 실제 노화된 배터리의 충방전 도중 검증하기 위한 test profile 및 experimental setup을 나타낸다. 검증은 전기자동차의 주행 환경을 모사한 Highway Fuel Economy Test Cycle(HWFET)를 based로 evaluation pattern이 제시된다. Chamber 내에 target battery를 세팅하고 test profile이 인가될 동안 전류 및 전압 데이터 수집을 위한 sensing wire를 부착한다. 충전 및 방전동안 수집되는 raw data는 protection 기능이 포함된 master BMS와 연결되며 알고리즘이 탑재된 AI embedded BMS는 master BMS로부터 voltage와 current를 수신한다. 최종적으로 AI embedded BMS는 SOH 값을 추정하며 이의 값을 Host PC에 저장된다.

3.2 실시간 SOH 추정 결과




그림 5 Bi-directional LSTM 기반 실시간 SOH 추정 결과

Fig. 5 Detailed configuration and development of Yocto project

Fig 5는 Bi-directional LSTM algorithm을 estimation model로 사용했을 때의 추정 결과이다. Estimation SOH는 reference SOH와 비교했을 때, 일정한 trend로 낮게 형성된다. 이는 training data set를 구성하는 과정에서 단일 셀 데이터만을 사용하지 않았으며, test data로 사용되는 battery sample의 experimental setup이 training data set의 experimental setup과 상이하기 때문으로 유추된다. 또한 estimated SOH는 일정한 값을 유지하는 것이 아니라, 간헐적인 noise 형태를 띄면서 random 한 값으로 증가 혹은 감소하는 형태를 나타낸다. Bi-directional LSTM model의 경우, noise 형태의 불특정된 값을 추정하는 현상이 evaluation profile내에 골고루 분포하며, 이는 test experimental setup 환경에 따라 변화할 수 있다. 실시간 SOH 추정 결과, 최대 에러는 3.0501%, 최소 에러는 0.3680%로 성능이 도출된다.

3. 결론

본 논문에서는 실시간 SOH 추정을 위해 배터리의 내부 전기화학적 상태와 밀접한 라벨링 기준을 설정하고, Ohmic Resistance 기반의 학습 데이터 셋을 구성하였다. 시계열 예측 모델로 Bi-directional LSTM이 선정되었으며, 구축된 알고리즘의 임베디드를 위한 Yocto project가 구성된다. HWFET와 UDSS가 혼합된 형태의 Evaluation profile로 실시간 SOH 추정 성능이 검증되며, 최대 3.0501%, 최소 0.3680%의 오차율이 도출된다.

이 논문은 현대자동차(모델 융합형 기술 기반 배터리 상태 진단 기술 고도화 개발)와 2022년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원(No. 2022-1711152629, 대규모 분산 에너지 저장장치 인프라의 안전한 자율운영 및 성능 평가를 위한 지능형 SW 프레임 워크 개발)의 지원을 받아 수행된 연구임

참고 문헌

[1] Hua, Yang, et al. "Sustainable value chain of retired lithium-ion batteries for electric vehicles." Journal of Power Sources 478 (2020): 228753.